

АДАПТИВНЫЕ МЕТОД И НЕЛИНЕЙНЫЕ АЛГОРИТМЫ ОЦЕНИВАНИЯ И НАВИГАЦИИ БЕСПИЛОТНЫХ АППАРАТОВ В УСЛОВИЯХ СТРУКТУРНОЙ И ПАРАМЕТРИЧЕСКОЙ НЕОПРЕДЕЛЕННОСТИ¹

Амосов О.С., Амосова С.Г.

Институт проблем управления им. В.А. Трапезникова РАН, Москва, Россия

osa18@yandex.ru, amosovasg@yandex.ru

Аннотация. Рассматриваются метод и нелинейные алгоритмы для адаптивного оценивания и навигации беспилотных аппаратов при структурной и параметрической неопределенности. Обсуждается целесообразность использования для синтеза нейросетевых алгоритмов. Дается иллюстрирующий адаптивный алгоритм при комплексной обработке навигационной информации.

Ключевые слова: беспилотный аппарат, адаптивное оценивание, метод, алгоритм, структурная и параметрическая неопределенность, интеллектуальная технология, нейронная сеть.

Введение

Знание точных моделей, представленных в виде случайных процессов или временных стохастических последовательностей, является важным при объединении алгоритмов обработки навигационной информации для беспилотных аппаратов (БА). Однако, на практике исследователи часто сталкиваются с ситуацией, когда эти модели известны лишь с определенной степенью неточности. В таких случаях могут возникать как параметрическая, так и структурная неопределенности [1–4].

При параметрической неопределенности математические модели динамической системы и системы измерений определены, но не все их параметры известны. Это может быть связано с недостаточными данными, ошибками измерения или изменениями в системе, которые не были учтены в математической модели. В случае структурной неопределенности математические модели системы и системы измерений известны не полностью. Кроме того, неизвестными могут быть и некоторые параметры этих моделей, или неправильное предположение о том, какие взаимосвязи между параметрами существуют [1–4].

В полной мере это касается беспилотных аппаратов, показания инерциальных навигационных систем (ИНС) которых необходимо корректировать во время движения за счет комплексной обработки измерений, доступных от дополнительных источников измерений.

В решении задач оценивания и навигации наиболее распространены методы и алгоритмы нелинейной фильтрации в рамках байесовской методологии. Эти методы обеспечивают единый подход как к синтезу алгоритмов, так и к исследованию их точности [5, 6]. Наиболее широкое применение на практике нашли алгоритмы калмановского типа – различные модификации фильтра Калмана (ФК) [5–7].

В последние годы получают развитие нейросетевые методы оценивания [7–14]. Достоинством нейронных сетей является возможность реализации нелинейных алгоритмов и способность к обучению и переобучению, что позволяет реализовать адаптивные алгоритмы [10–14]. Еще одним достоинством нейронных сетей является их успешное применение для прогнозирования временных рядов [15], что важно при реализации комплексирования измерений от разнородных источников навигационных данных [16, 17]. Для задачи прогнозирования хорошо зарекомендовали сети LSTM (Long Short-Term Memory). Из новых тенденций необходимо отметить трансформеры [18].

Поэтому целью данной статьи является изложение адаптивного метода и нелинейных алгоритмов оценивания (фильтрации) и навигации БА с использованием интеллектуальных технологий на основе нейронных сетей и машинного обучения.

1. Формулировка задачи адаптивной фильтрации оценивания

Требуется найти оптимальную оценку временной стохастической последовательности (в.с.п.) $x_i = (x_{i1}, \dots, x_{in})^T$, для которой индекс i соответствует моменту времени t_i , а n – ее размерность. В.с.п. определяется математической моделью динамической системы вида

¹ Исследование выполнено за счет гранта Российского научного фонда № 24-29-00671, <https://rscf.ru/project/24-29-00671/>

$$\mathbf{x}_i = \Phi_i(\mathbf{x}_{i-1}, \boldsymbol{\theta}_{i-1}, \mathbf{n}_i). \quad (1)$$

Выходом системы (1) для момента времени t_i являются измерения \mathbf{y}_i , размера m , которые определяются уравнением (2)

$$\mathbf{y}_i = \mathbf{s}_i(\mathbf{x}_i, \boldsymbol{\theta}_i, \mathbf{v}_i). \quad (2)$$

Задача решается при недостатке априорных сведений [1–4]: 1) о математической модели $M(t)$ (1), (2); 2) о векторе неизвестных параметров $\boldsymbol{\theta}_i = (\theta_{i1}, \dots, \theta_{il})^T$, размера l .

В представленной модели (1) и (2) $\Phi_i(\bullet)$, $\mathbf{s}_i(\bullet)$ – нелинейные вектор-функции, размера n и m ; \mathbf{n}_i , \mathbf{v}_i – независимые между собой и от начального вектора состояния \mathbf{x}_0 в.с.п., размера d и r .

Если используется модель аддитивных шумов \mathbf{n}_i и \mathbf{v}_i , то в.с.п. (1) и (2) имеют вид [5, 6]:

$$\mathbf{x}_i = \Phi_i(\mathbf{x}_{i-1}, \boldsymbol{\theta}_{i-1}) + \Gamma_i(\mathbf{x}_{i-1})\mathbf{n}_i; \quad (3)$$

$$\mathbf{y}_i = \mathbf{s}_i(\mathbf{x}_i, \boldsymbol{\theta}_i) + \mathbf{v}_i. \quad (4)$$

В случае, когда динамическая система является линейной, ее математическая модель (1) и (2) может быть записана [5, 6]:

$$\mathbf{x}_i = \Phi_i \mathbf{x}_{i-1} + \Psi_i \boldsymbol{\theta}_{i-1} + \Gamma_i \mathbf{n}_i, \quad \mathbf{w}_i = \Gamma_i \mathbf{n}_i; \quad (5)$$

$$\mathbf{y}_i = \mathbf{H}_i \mathbf{x}_i + \mathbf{O}_i \boldsymbol{\theta}_i + \mathbf{v}_i. \quad (6)$$

Здесь Φ_i , Γ_i , Ψ_i , \mathbf{H}_i и \mathbf{O}_i являются известными матрицами размера $n \times n$, $n \times d$, $n \times l$, $m \times r$ и $m \times l$ соответственно.

Задачу оценивания в.с.п. \mathbf{x}_i на основе в.с.п. измерений \mathbf{Y}_i можно свести к более простой задаче оценивания одного вектора \mathbf{x} по измеренным значениям другого вектора \mathbf{y} . Для этого достаточно предположить, что в качестве фигурирующих здесь векторов \mathbf{x} и \mathbf{y} выступают соответственно \mathbf{x}_i и \mathbf{Y}_i : $\mathbf{x} \equiv \mathbf{x}_i$, $\mathbf{y} \equiv \mathbf{Y}_i = [\mathbf{y}_1^T, \dots, \mathbf{y}_{i-1}^T, \mathbf{y}_i^T]^T$.

При использовании байесовского подхода для решения задачи фильтрации, вычислении $\tilde{\mathbf{x}}(\mathbf{y})$, критерием оптимизации является следующий [5, 6]:

$$J = E[(\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y}))^T (\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y}))] = E\|\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y})\|^2 = \iint \|\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y})\|^2 f(\mathbf{x}, \mathbf{y}) d\mathbf{x} d\mathbf{y}. \quad (7)$$

Здесь E – символ математического ожидания.

При использовании метода наименьших квадратов (МНК) для решения задачи фильтрации, вычислении $\tilde{\mathbf{x}}(\mathbf{y})$, критерием оптимизации является следующий [5, 6]

$$I(\mathbf{x}) = (\mathbf{y} - \mathbf{s}(\mathbf{x}))^T (\mathbf{y} - \mathbf{s}(\mathbf{x})) = \sum_{i=1}^m (y_i - s_i(\mathbf{x}))^2. \quad (8)$$

2. Решение задачи адаптивного оценивания

2.1. Общее решение задачи адаптивного оценивания

Предполагается, что при наличии структурной неопределенности система представляется конечным числом моделей M^j , соответствующих заданному набору гипотез h^j :

$$M^j \rightarrow h^j, j = \overline{1, J}. \quad (9)$$

Для каждой гипотезы j , $j = \overline{1, J}$, в уравнениях (1)–(6) Φ_i , \mathbf{s}_i , Γ_i , \mathbf{H}_i и Ψ_i являются известными вектор-функциями или матрицами; \mathbf{n}_i , \mathbf{v}_i и $\mathbf{n}_{\theta i}$ – белозумные центрированные гауссовские последовательности соответствующих размерностей.

Наиболее часто в качестве математических моделей для уточнения вектора $\boldsymbol{\theta}_i$ выбирают следующие:

$$\boldsymbol{\theta}_i = \boldsymbol{\theta}_{i-1}; \boldsymbol{\theta}_i = \boldsymbol{\theta}_{i-1} + \mathbf{n}_{\boldsymbol{\theta}_i}; \boldsymbol{\theta}_i = \mathbf{g}_i(\boldsymbol{\theta}_{i-1}) + \mathbf{n}_{\boldsymbol{\theta}_i}, \quad (10)$$

где $\mathbf{n}_{\boldsymbol{\theta}_i}$ – в.с.п. размерности l , а \mathbf{g}_i – в общем случае нелинейная вектор-функция. Кроме того, для идентификации вектора $\boldsymbol{\theta}_i$ используется модель полумарковского процесса [3, 11].

Можно выделить два подхода для решения поставленной задачи.

В первой группе алгоритмов адаптации необходимо выбрать гипотезу, которой соответствует максимальное значение апостериорной вероятности $P\{M^j / \mathbf{Y}_i\} \rightarrow h^j, j = \overline{1, J}$. После выбора гипотезы вычисляются оптимальные байесовские оценки векторов $\mathbf{x}_i^j, \boldsymbol{\theta}_i^j$ [2].

Во втором подходе рассчитываются для всех гипотез $h^j, j = \overline{1, J}$ апостериорные вероятности. Затем находятся оптимальные байесовские оценки векторов $\mathbf{x}_i^j, \boldsymbol{\theta}_i^j$, как сумма взвешенных оценок этих векторов для соответствующих гипотез [3–5].

Оптимальные байесовские оценки векторов $\mathbf{x}_i^j, \boldsymbol{\theta}_i^j$ вычисляются как взвешенные значения этих векторов по всем гипотезам, где веса соответствуют апостериорным вероятностям этих гипотез [3–5].

Для реализации алгоритмов оценивания наиболее часто используется традиционный метод на основе банка фильтров Калмана (ФК) [2–4]. В данном методе применяется блок фильтров, каждый из которых настроен к определенной гипотезе о математической модели, представляющей динамику системы. Невязки фильтров используются для расчета апостериорных вероятностей гипотез, связанных с различными моделями.

2.2. Решение задачи адаптивного оценивания с использованием нейросетевых фильтров

Использование нейросетевых технологий для оценивания возможно для решения задач фильтрации и прогнозирования.

1. Задача фильтрации. Предлагается метод, в котором используется набор нейросетевых структур, синтезированных на основе искусственных нейронных сетей, обучаемых с учителем. Для адаптации в режиме реального времени предлагается использовать механизм подкрепления.

По существу синтезируется с использованием нейросетевых технологий класс зависящих от параметров функций, используемых для фильтрации. Точно также можно вести классы зависящих от параметров функций, реализуемые на основе методов нечеткого вывода, регрессии, вейвлетов [13, 14]. Выбор гипотезы, которой соответствует максимальная апостериорная вероятность, производится специально обученным нейросетевым алгоритмом.

Отличие предлагаемого метода с вводом класса зависящих от параметров нейросетевых функций (например, нейросетевых) от существующего, на основе банка ФК, состоит в том, что каждый из синтезируемых при обучении фильтров является, в общем случае, нелинейным. Характерной особенностью этого подхода является наличие обучающего датасета.

Для решения задачи оценивания навигационных параметров предлагается использовать нейросетевые алгоритмы, которые обеспечивают точности оценок, такие же, как и традиционные алгоритмы при байесовском, небайесовском подходах и методе наименьших квадратов [7–14]. В рамках байесовского подхода, если в основе построения нейросетевых алгоритмов лежат те же предположения об априорной информации о моделях динамики объектов, помех и шумов, что и для традиционных алгоритмов, то нейросетевые алгоритмы тождественны традиционным [10]. Однако они могут дать преимущества с вычислительной точки зрения. Кроме того, в случае необходимости адаптации к изменениям моделей динамики или окружающей среды возможна настройка уже синтезированных нейросетевых алгоритмов с использованием обучения с технологией подкрепления [12, 14].

Проанализируем предложенный подход к оцениванию, реализованный с использованием нейросетевых алгоритмов, при наличии обучающего набора данных при *байесовском методе* [13, 14].

1) Представляется класс функций $\tilde{\mathbf{x}}(\mathbf{y}, \tilde{\mathbf{W}})$, определяемых параметрически.

2) Формируется критерий оптимизации на основе среднеквадратичного отклонения [13, 14]

$$\tilde{J}(\tilde{\mathbf{W}}) = \frac{1}{N} \sum_{j=1}^N \left(\mathbf{x}^{(j)} - \tilde{\mathbf{x}}^{(j)}(\mathbf{y}^{(j)}, \tilde{\mathbf{W}}) \right)^T \left(\mathbf{x}^{(j)} - \tilde{\mathbf{x}}^{(j)}(\mathbf{y}^{(j)}, \tilde{\mathbf{W}}) \right), \quad (11)$$

с учетом обучающего набора данных

$$\left\{ (\mathbf{y}^{(j)}, \mathbf{x}^{(j)}) \right\}_{j=1}^N, \quad (12)$$

где $\tilde{\mathbf{x}}^{(j)}(\mathbf{y}^{(j)}, \tilde{\mathbf{W}})$ – является оценкой, которая формируется.

3) Оптимизация критерия (11) осуществляется путем минимизации эмпирического риска [13]

$$P \left\{ \sup_{\tilde{\mathbf{W}}} |J(\tilde{\mathbf{W}}) - \tilde{J}(\tilde{\mathbf{W}})| > \varepsilon \right\} \rightarrow 0, \text{ при } N \rightarrow \infty,$$

где ε – обозначает заданную точность; $J(\tilde{\mathbf{W}}) = E \|\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y}, \tilde{\mathbf{W}})\|^2$.

4) Для процесса минимизации критерия (11) задействован нейросетевой алгоритм, использующий нейронную сеть для выполнения преобразования

$$\tilde{\mathbf{x}}^{NN}(\mathbf{y}) = \mathbf{K}^{NN}(\mathbf{y}, \tilde{\mathbf{W}}). \quad (13)$$

Здесь \mathbf{y} – обозначает входные данные системы, а $\tilde{\mathbf{W}}$ – представляет собой матрицу параметров нейронной сети, которая включает в себя массив коэффициентов смещений и весов.

5) В итоге находится $\tilde{\mathbf{W}}^*$, минимизирующая (11). На основе полученного измерения \mathbf{y} по формуле (13) вычисляется значение оценки $\tilde{\mathbf{x}}^{NN}(\mathbf{y})$.

Рассмотрим следующее решение данной задачи оценивания с использованием нейросетевых систем в рамках **МНК**. Это решение способно обеспечить эффективную работу нейросетевых алгоритмов в режиме онлайн [12].

1) Аналогичный этап, как в байесовском методе.

2) Отличается от байесовского тем, что отсутствует набор данных в виде пар $\{\mathbf{y}^{(j)}, \mathbf{x}^{(j)}\}_{j=1}^N$, но имеется функция $\mathbf{s}(\mathbf{x})$, по которой производится расчет среднеквадратического критерия оптимизации [12]

$$\tilde{I}(\tilde{\mathbf{W}}) = \{\mathbf{y} - \mathbf{s}[\tilde{\mathbf{x}}(\mathbf{y}, \tilde{\mathbf{W}})]\}^T \{\mathbf{y} - \mathbf{s}[\tilde{\mathbf{x}}(\mathbf{y}, \tilde{\mathbf{W}})]\} = \sum_{i=1}^m \{y_i - s_i[\tilde{\mathbf{x}}(\mathbf{y}, \tilde{\mathbf{W}})]\}^2, \quad (14)$$

Здесь $\tilde{\mathbf{x}}(\mathbf{y}, \tilde{\mathbf{W}})$ – является оценкой, которая формируется. Следует отметить, что в данном случае возможно использования набора данных $\{\mathbf{y}^{(j)}\}_{j=1}^N$ для расчета критерия (14).

3) Оптимизация критерия (14) осуществляется путем минимизации эмпирического риска

$$P \left\{ \sup_{\tilde{\mathbf{W}}} |I(\tilde{\mathbf{W}}) - \tilde{I}(\tilde{\mathbf{W}})| > \varepsilon \right\} \rightarrow 0, \text{ при } N \rightarrow \infty,$$

где ε – обозначает заданную точность; $I(\tilde{\mathbf{W}}) = E \|\mathbf{y} - \mathbf{s}[\tilde{\mathbf{x}}(\mathbf{y})]\|^2$.

4) Для процесса минимизации критерия, задействован нейросетевой алгоритм, как и в случае байесовского подхода $\tilde{\mathbf{x}}^{NN}(\mathbf{y}) = \mathbf{K}^{NN}(\mathbf{y}, \tilde{\mathbf{W}})$.

5) По завершению обучения системы в реальном времени, значение оценки определяется на основе входящего измерения \mathbf{y} , используя формулу (13).

Одним из ключевых направлений исследований, имеющим большой потенциал, является создание адаптивных алгоритмов для оценивания и фильтрации.

В случае априорной неопределенности перспективным подходом для адаптации нейросетевых алгоритмов рассматривается возможность применения **обучения с механизмом подкрепления** (Рис. 1) [12]. Следует отметить, что для оценки состояния систем особенно перспективно применение НС с глубоким обучением, включая сверточные и рекуррентные слои, например, слои LSTM (англ. Long Short-Term Memory) или блоки GRU (англ. Gated Recurrent Units).

2. Задача прогнозирования. При комплексировании измерений от нескольких измерителей можно использовать адаптивные свойства нейросетевых алгоритмов. В этих задачах для построения нейросетевых алгоритмов помимо текущих измерений имеется датасет для их обучения. Подобные задачи характерны, например, для комплексной обработки информации от инерциальной навигационной системы и данных от спутниковой навигационной системы (СНС) [10]. При этом данные от СНС как раз и используются для составления датасета, необходимого для обучения нейросетевых алгоритмов. Основное предназначение нейросетевых алгоритмов состоит в прогнозировании поведения БА по данным СНС, когда данные от СНС становятся недоступными. Для

решения задач прогнозирования могут использоваться нереккуррентные и рекуррентные нейросетевые алгоритмы. Для повышения их быстродействия предлагается использование декомпозиции алгоритмов [13].

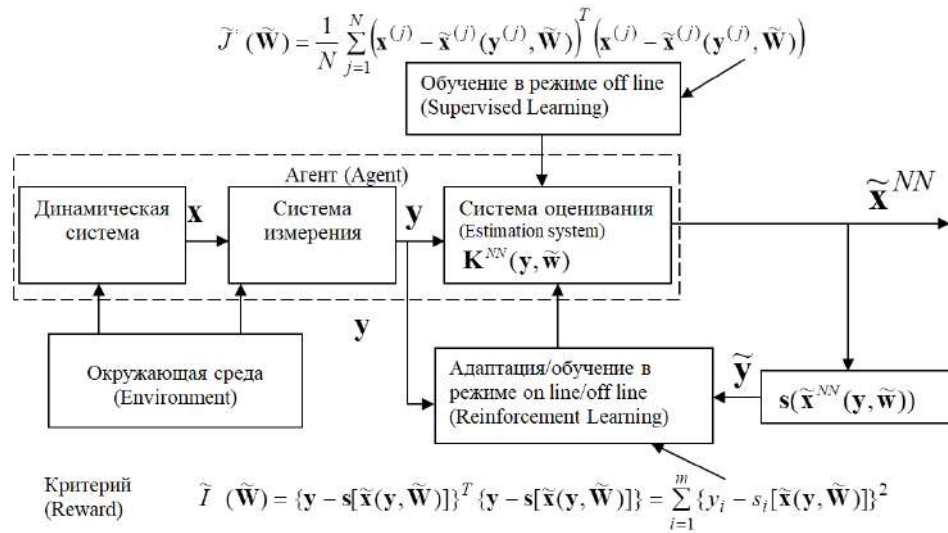


Рис. 1. Адаптация на основе машинного обучения с подкреплением

Существенно отметить, что набор моделей поведения объекта, который определяется уравнениями (1)–(6) реализуется с помощью нейронной сети. Необходим прогноз поведения БА при пропадании корректирующих измерений.

Рассмотрим решение, сформулированной задачи прогноза, с использованием временных рядов для БА [15]. Оцениваемый вектор состояния БА $\lambda_i = [(\lambda_i^X)^T, (\lambda_i^Y)^T, (\lambda_i^Z)^T]^T$, $i = 0, 1, \dots$, $\lambda_i^j = [\lambda_i^j, V_i^j, a_i^j]^T$, $j = X, Y, Z$ представляет собой координаты, проекции скоростей и ускорений.

Требуется, используя случайную последовательность измерений координат и проекций скоростей и ускорений БА $\xi_k = [(\xi_k^X)^T, (\xi_k^Y)^T, (\xi_k^Z)^T]^T$, $\xi_i^j = [\xi_{1i}^j, \xi_{2i}^j, \xi_{3i}^j]^T$, $j = X, Y, Z$, найти оптимальную оценку $\tilde{\lambda}_{i/k}$, которая минимизирует среднеквадратический критерий $J_{i/k} = E[(\lambda_i - \tilde{\lambda}_{i/k})^T (\lambda_i - \tilde{\lambda}_{i/k})]$. Здесь E – символ математического ожидания. Заметим, что случай $k > i$ соответствует задаче оценки прогноза состояния.

Оптимальную оценку $\tilde{\lambda}_{i/k}$ определим как $\tilde{\lambda}_{i/k} = \varphi_i(\xi_k)$. В конечном итоге, для решения задачи прогноза положения БА требуется определить нелинейную функцию $\varphi_i(\bullet)$ [13].

Для решения задачи оценки прогноза $\tilde{\lambda}_{i/k} = \varphi_i(\xi_k)$ могут быть выбраны байесовский и небайесовский подходы, метод наименьших квадратов [13]. В рамках каждого метода оценка прогноза $\tilde{\lambda}_{i/k} = \varphi_i(\xi_k)$ может быть представлена в виде $\tilde{\lambda}_{i/k} = \varphi_i(\xi_k, \mathbf{W})$, где нелинейное отображение $\varphi_i(\bullet)$ параметризуется вектором \mathbf{W} . Для нахождения \mathbf{W} может быть использовано машинное обучение с использованием нейронных сетей [13].

3. Пример решения задачи адаптивного оценивания

Рассмотрим иллюстрирующий пример адаптивной фильтрации при комплексировании показаний спутниковой навигационной системы и инерциальной навигационной системы на основе инвариантной схемы [5].

Рассматривается задача уточнения координат ИНС по данным СНС [5], когда спутниковые данные могут пропадать. Здесь можно говорить о возможных адаптивных свойствах получающихся алгоритмов [10]. Простейшим примером может служить задача комплексной обработки для уточнения высоты БА с использованием измерений от СНС [5].

Следуя [5] предположим, что имеются измерения

$$y_i^I = h_i + \Delta y_i^I, y_i^II = h_i + \Delta y_i^{II},$$

где $h_i, y_i^I, y_i^{II}, \Delta y_i^I, \Delta y_i^{II}$ – скалярные последовательности, описывающие поведение истинных значений координаты, показаний ИНС (I=ИНС), спутниковой системы (II=СНС) и их ошибок. Будем считать, что ошибки ИНС $\Delta y_i^I = \varepsilon_i^I + v_i^I$ определяются суммой дрейфа, описываемого винеровским процессом, постоянной и белым шумом составляющих [2], т.е.

$$\Delta h_i = \Delta h_{i-1} + \sigma_w^h w_i, \quad \Delta h_0 = d_i = d_{i-1} = d, \quad \varepsilon_i = d_i + \Delta h_i + v_i^I,$$

где Δh_i – дрейф координаты h_i ; σ_w^h – коэффициент, определяющий СКО порождающего шума дрейфа; d – постоянная составляющая погрешности, v_i^I – белый шум измерений. Ошибки СНС содержат только белую составляющую $\Delta y_i^{II} = v_i^{II}$.

Ставится задача нахождения оценки дрейфа Δh_i координаты h_i на фоне белого шума. Следуя инвариантной схеме [5], искомую оценку можем сформировать в виде

$$\tilde{h}_i = y_i^I - \tilde{\varepsilon}_i^I, \quad \tilde{\varepsilon}_i^I = H_i^I \tilde{h}_i,$$

которую отыскиваем с помощью линейного фильтра Калмана.

Исследования проведены при следующих параметрах: интервал дискретизации $T = t_i - t_{i-1} = 0,004$ с; начальная высота координата $h_0 = 0$ м; начальная скорость БА $V_0^h = 0,15$ м/с; постоянная составляющая ошибки ИНС неизвестна, считаем, что ее математическое ожидание $m_h = 0$ и среднеквадратическое отклонение (СКО) $\sigma^d = 1$ м; коэффициент, определяющий СКО порождающего шума дрейфа $\sigma_w^h = 0,5$ м; СКО дискретного белого шума (д.б.ш.) измерений ИНС $\sigma_v^I = 1$ м; СКО д.б.ш. измерений СНС $\sigma_v^{II} = 0,5$ м. Будем считать, что измерения от СНС поступают с 1 по 10000 отчет, с 100001 по 14000 отсчеты становятся недоступны и появляются с 14001 отсчета. Пример реализации измерений и результаты решения алгоритма оценивания приведены на рис. 2–3.

Для прогнозирования поведения БА по данным СНС, когда данные от СНС становятся недоступными, используется рекуррентная сеть с несколькими слоями: в роли скрытого слоя использовался слой LSTM, число нейронов в котором варьировалось от 64 и выше; за слоем LSTM следует полносвязный слой с 64 нейронами и выходной слой регрессии.

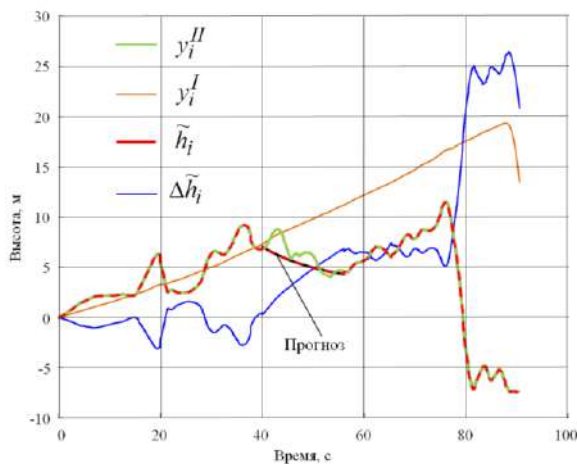


Рис. 2. Оценка высоты и ее дрейфа




Рис. 3. Погрешность оценки высоты

Из рис. 2–3 видно, что погрешность определения высоты не превышает 0,5 м при наличии спутниковых данных и увеличивается в случае, когда данные от СНС пропадают, а вместо них используются значения прогноза.

4. Заключение

Изложен подход к решению задачи адаптивного оценивания. Формулируется постановка задачи при структурной и параметрической неопределенности. Для ее решения рассматриваются метод и нелинейные алгоритмы, основанные на вводе класса зависящих от параметров функций, которые

реализуются на нейросетевых структурах. Рассмотренный подход позволяет реализовать адаптивные алгоритмы нелинейного оценивания, которые используют возможности обучения и дообучения нейросетевых структур.

Также обсуждается возможность адаптивных свойств с использованием обучения с механизмом подкрепления. Адаптивные свойства нелинейных нейросетевых алгоритмов используются для прогнозирования временных рядов при реализации комплексирования измерений от разнородных источников навигационных данных. Рассмотрена задача адаптации при уточнении координат ИНС по данным СНС, когда спутниковые данные пропадают. Для прогноза поведения подвижного объекта используется рекуррентная нейронная сеть со слоем LSTM.

Литература

1. Тихонов В.И., Харисов В.Н. Статистический анализ и синтез радиотехнических устройств и систем. – М.: Радио и связь, 1991.
2. Степанов О.С., Моторин А.В. Методы адаптивного оценивания в задачах обработки навигационной информации // XIII Всероссийское совещание по проблемам управления (ВСПУ-2019): сборник конференции. – М.: ИПУ РАН, 17-20 июня 2019. – С. 1359–1366.
3. Кузьмин С.З. Цифровая радиолокация. Введение в теорию. – Киев: Издательство КВиЦ, 2000.
4. Bar-Shalom Y., Li X.-Rong, and Thiagalingam Kirubarajan Estimation with Applications to Tracking and Navigation. – New York: John Wiley & Sons, 2001.
5. Степанов О.А. Основы теории оценивания с приложениями к задачам обработки навигационной информации. – 3-е изд., исправ. и доп. Ч. 1. Введение в теорию оценивания. – СПб: ГНЦ РФ АО «Концерн «ЦНИИ «Электроприбор», 2017. – 509 с.
6. Степанов О.А. Основы теории оценивания с приложениями к задачам обработки навигационной информации. – 3-е изд., исправ. и доп. Ч. 2. Введение в теорию фильтрации. – СПб: ГНЦ РФ АО «Концерн «ЦНИИ «Электроприбор», 2017. – 428 с.
7. Stepanov O.A., Amosov O.S., Toropov A.V. Comparison of Kalman-type Algorithms in Nonlinear Navigation Problems for Autonomous Vehicles // IFAC Proceedings Volumes (IFAC-PapersOnline). – 2007. – Vol. 6, Pt 1. – P. 493–498.
8. Степанов О.А., Амосов О.С. Байесовское оценивание с использованием нейронной сети // Авиакосмическое приборостроение. – 2004. – № 6. – С. 46–55.
9. Степанов О.А., Амосов О.С. Оптимальная линейная фильтрация с использованием нейронной сети // Гироскопия и навигация. – 2004. – № 3 (46). – С. 14–29.
10. Степанов О.А., Амосов О.С. Применение нейронных сетей в нелинейных задачах обработки навигационной информации // XIII Межд. конф. по интегрированным навигационным системам: сборник тр. СПб: ГНЦ РФ АО «Концерн «ЦНИИ «Электроприбор». – 2006. – С. 178–182.
11. Амосов О.С., Амосова С.Г. Адаптивное оценивание процессов с разладкой в навигационных приложениях с использованием машинного обучения // XXVIII Межд. конф. по интегрированным навигационным системам: сборник тр. СПб: ГНЦ РФ АО «Концерн «ЦНИИ «Электроприбор», 2021. – С. 325–328.
12. Амосов О.С., Амосова С.Г. Машинное обучение с подкреплением для задач оптимального и адаптивного оценивания в навигационных приложениях // XXIX Межд. конф. по интегрированным навигационным системам: сборник тр. СПб: ГНЦ РФ АО «Концерн «ЦНИИ «Электроприбор», 2022. – С. 300–303.
13. Amosov O.S., Vaena S.G. Decomposition Synthetic Approach for Optimum Nonlinear Estimation // IFAC-PapersOnLine, 2015. – Т. 48, № 11. – P. 819–824.
14. Амосов О.С., Амосова С.Г. Интеллектуальные технологии совместной навигации и функционирования подвижных объектов в разных физических средах // Информационные технологии, 2025. – Т. 31, № 1. – С. 24–34.
15. Амосов О.С., Амосова С.Г. Нейросетевое прогнозирование положения человека по непрерывному видеопотоку при совместной работе человека и робота // Датчики и системы. № 2023. – № 2 (267). – С. 59–64.
16. Амосов О.С., Амосова С.Г. Концепция совместной навигации и связи гетерогенной группы автономных беспилотных аппаратов, находящихся в разных средах // Пятнадцатая международная конференция “Управление развитием крупномасштабных систем” (MLSD'2022): сборник тр. Москва: ИПУ РАН, 2022. – С. 865–873.
17. Амосов О.С., Амосова С.Г. Особенности алгоритмов навигации для разных типов беспилотных аппаратов // Семнадцатая международная конференция “Управление развитием крупномасштабных систем” (MLSD'2024): сборник тр. Москва: ИПУ РАН, 2024. – С. 727–733.
18. Gerasimenko N.A., Chernyavsky A.S., Nikiforova M.A. RuSciBERT: A transformer language model for obtaining semantic embeddings of scientific texts in Russian // Dokl. Math. – 2022. – Vol. 106, № S1. – P. S95–S96.